

An Approach to Managing and Organizing Text Documents Using Intelligent Text Analysis

Azamsadat Parei

MA in Information Technology Engineering - electronic Commerce;
K. N. Toosi University of Technology;
as.parei@gmail.com

Hodjat Hamidi

PhD in Information Technology Engineering Group; Assistant
Professor; Department of Industrial Engineering; K. N. Toosi
University of Technology;
Corresponding Author h_hamidi@kntu.ac.ir

Iranian Journal of
**Information
Processing and
Management**

Iranian Research Institute
for Information Science and Technology
(IranDoc)

ISSN 2251-8223

eISSN 2251-8231

Indexed by SCOPUS, ISC, & LISTA

Vol. 32 | No. 4 | pp. 1171-1202

Summer 2017

<https://doi.org/10.35050/JIPM010.2017.029>



Received: 05, Jul. 2016

Accepted: 23, Aug. 2016

Abstract: Regarding the fact that stored data occupies a large space in organizations and retention systems and information management that has been resulted in gigantic data warehouses, the need for extracting an appropriate model is felt increasingly. Text mining is one of the most significant methods for extracting a useful and appropriate model that helps organizations in achieving their goals through extraction and adaption of knowledge out of data sets. Those methods allow for a new horizon for trading and protecting intellectual property of authors' works. In this paper, a new approach is needed to decipher the text patterns to organize an intelligent text analysis. The main purpose of the paper is applying a proper method of preserving the works of writers, scholars and text documents. Regarding the number of those works and documentary management systems the size of available data has been increased considerably. In order to uncover the implicit knowledge out of this data with considerable usefulness for users a specific method is required that has been practiced in the data mining field. Much of this available data is unstructured or semi-structured text which one can use it in addition to data mining methods, technologies such as natural language processing, intelligent analysis and Science Statistics used.

Keywords: Text Search, Text Management, Intellectual Property, Information Extraction, Data Mining)

ارائه رویکردی برای مدیریت و سازماندهی اسناد متنی با استفاده از تجزیه و تحلیل هوشمند متن

اعظم السادات پوئی

کارشناسی ارشد مهندسی فناوری اطلاعات؛
دانشکده مهندسی صنایع؛ دانشگاه صنعتی خواجه
نصیرالدین طوسی as.parei@gmail.com

حجت‌اله حمیدی

دکتری مهندسی کامپیوتر - فناوری اطلاعات؛
استادیار؛ دانشکده مهندسی صنایع؛
دانشگاه صنعتی خواجه نصیرالدین طوسی؛
پدیده‌آور رابط h_hamidi@kntu.ac.ir



مقاله برای اصلاح به مدت ۱ روز نزد پدیدآوران بوده است.

پدیش: ۱۳۹۵/۰۶/۰۲

دریافت: ۱۳۹۵/۰۴/۱۵

فصلنامه | علمی پژوهشی
پژوهشگاه علوم و فناوری اطلاعات ایران
(ایرانداک)

شاپا (چاپی) ۲۲۵۱-۸۲۲۳

شاپا (الکترونیکی) ۲۲۵۱-۸۲۳۱

نمایه در SCOPUS، ISC، LISTA، و

jipm.irandoc.ac.ir

دوره ۳۲ | شماره ۴ | صص ۱۱۷۱-۱۲۰۲

تایستان ۱۳۹۶

<https://doi.org/10.35050/JIPM010.2017.029>



چکیده: با توجه به حجم عظیم داده‌های جمع‌آوری شده در سازمان‌ها و سیستم‌های نگهداشت و مدیریت اطلاعات که سبب شکل‌گیری انبار داده‌های بسیار بزرگ شده، نیاز به استخراج الگو از متون هر روز بیشتر احساس می‌شود. متن کاوی یکی از مهم‌ترین روش‌ها در استخراج الگوی مناسب است که به وسیلهٔ اقتباس یا استخراج دانش از مجموعه‌ای از داده‌ها به اهداف سازمان‌ها بسیار کمک می‌کند. این روش‌ها همچنین می‌توانند افق جدیدی را برای تجارت و حفاظت از مالکیت معنوی آثار نویسندگان به وجود آورند. در این مقاله با رویکردی جدید به کشف الگوهای متنی جهت سازماندهی و تجزیه و تحلیل هوشمند متن می‌پردازیم. هدف اصلی، به کارگیری الگوی مناسب در جهت حفظ آثار نویسندگان، محققان و اسناد متنی است. با توجه به حجم آثار نویسندگان و سیستم‌های مدیریت اسناد، حجم اطلاعات در دسترس نیز به شدت افزایش یافته است. برای کشف دانش موجود در این داده‌ها، که منفعت زیادی را برای کاربران اطلاعات به دنبال دارد، روش‌های خاصی مورد نیاز است که در حوزه داده کاوی به آن پرداخته شده است. بخش اعظم این داده‌های در دسترس به صورت متنی و بدون ساختار یا نیمه‌ساختارمند هستند که برای استفاده از آن‌ها می‌توان علاوه بر روش‌های مورد استفاده در داده کاوی، از فناوری‌هایی مانند پردازش زبان طبیعی، تجزیه و تحلیل هوشمند و علم آمار بهره گرفت.

کلیدواژه‌ها: کاوش متن، مدیریت متن، مالکیت معنوی، استخراج اطلاعات، داده کاوی

۱. مقدمه

داده کاوی^۱ به پردازش داده‌های عظیم و استخراج اطلاعات کاربردی از آن‌ها می‌پردازد (Saracoglu, Tutuncu, and Allahverdi 2007). داده‌ها ممکن است در چارچوب‌های داده‌های توصیفی مانند گزارش‌های کیفیت اسناد و یادداشت‌هایی برای کمک به مشتریان باشد (Kornfein and Goldfarb 2007). لذا، تلاش‌های تکنیکی و دستی برای هدایت کردن این منابع داده‌ای، به‌منظور کشف الگوها و داده‌های سودمند موجود در این منابع مورد نیاز است (Kornfein and Goldfarb 2007). از آنجا که بالای ۸۰ درصد از این اطلاعات به‌صورت متنی نگه‌داری می‌شوند، باور بر این است که متن کاوی ارزش بالقوه تجاری بالایی داشته باشد (Gupta, and Lehal 2009). انتقال این منابع مفید اطلاعاتی به چارچوب‌های قابل استفاده باعث پیشرفت فناوری‌های آینده است و به کیفیت خدمات‌رسانی کمک خواهد کرد. با گسترش روزافزون اینترنت و فناوری‌های اطلاعاتی، حجم اطلاعات در دسترس بسیار افزایش یافته است (Weng and Lin 2003). از آنجا که پردازش دستی این داده‌های متنی کاری طاقت‌فرساست، به روش‌های متن کاوی^۲ احتیاج هست (Hashimi, Hafez, and Mathkour 2015). بنابراین، افراد وقت بیشتری را صرف پالایش کردن اطلاعات می‌کنند (Weng and Lin 2003). متن کاوی با اطلاعات متنی یا بدون ساختار^۳، برای استخراج اطلاعات بامعنا و دانش از مقدار زیادی اطلاعات سروکار دارد. امروزه، راه‌حل‌های متنوعی برای مدیریت و سازماندهی مقدار زیادی از اسناد متنی و به‌دست آوردن اطلاعات مفید از این داده‌ها (متن کاوی) در حال پیشرفت و تحقیق است. جست‌وجوی سند مشابه به‌عنوان بخشی از متن کاوی در نظر گرفته‌شده و روش‌های هوش مصنوعی^۴ زیادی در این مراحل مورد استفاده قرار گرفته‌اند. از این رو، این موضوع به‌عنوان یکی از عملیات اساسی مدیریت اسناد مشهود است (Saracoglu, Tutuncu, and Allahverdi 2008). علاوه بر این، یافتن اسناد مرتبط و مشابه با اسناد موجود از حجم عظیمی از اسناد، نقش مهمی را در متن کاوی ایفا می‌کند. تمامی این مباحث ما را به‌سوی طراحی یک سیستم جست‌وجوی مؤثرتر سوق می‌دهد (همان). متن کاوی فرایند تجزیه و تحلیل اسناد به‌وسیله جست‌وجوی الگوها در متون به زبان طبیعی و به‌منظور استخراج اطلاعات برای اهداف خاص است (Weng and Lin 2003). متن کاوی شاخه‌ای از حوزه داده کاوی است که سعی در یافتن الگوهای

1. data mining

2. text mining

3. unstructured

4. artificial intelligence

جالب توجه از پایگاه داده‌های بزرگ دارد و طی آن کشف اطلاعات جدید یا استخراج خودکار اطلاعات از منابع مکتوب مختلف به وسیله رایانه امکان‌پذیر می‌شود. متن کاوی که تحت عناوین تجزیه و تحلیل هوشمند متن، کاوش داده‌های متنی و کشف دانش از متون نیز شناخته می‌شود، به‌طور کلی، به فرایند استخراج اطلاعات و دانش جالب توجه و غیربدهی از متن بدون ساختار اشاره دارد (Gupta, and Lehal 2009).

این مقاله به‌صورت زیر سازماندهی شده است: پس از مقدمه‌ای کوتاه در بخش اول، در بخش دوم به مروری درباره ادبیات موضوع در زمینه داده کاوی در اسناد متنی می‌پردازیم؛ در بخش سوم، ارتباط متن کاوی با حوزه‌های دیگر نظیر کشف دانش در پایگاه داده و وب کاوی را بیان می‌کنیم؛ در بخش چهارم، به تعریف دقیق و مزایای متن کاوی اشاره می‌کنیم؛ در بخش پنجم، به مراحل اصلی متن کاوی که شامل: ۱. پیش‌پردازش که خود از بخش‌های مدل فضای برداری و پیش‌پردازش زبان‌شناختی تشکیل شده است، ۲. تولید و استخراج ویژگی، و ۳. انتخاب ویژگی است، پرداخته می‌شود؛ در بخش ششم، به فازهای اصلی فرایند متن کاوی می‌پردازیم؛ در بخش هفتم، مدل پیشنهادی توضیح داده می‌شود؛ در بخش هشتم، یافته‌های مقاله بررسی می‌گردد؛ و در بخش نهم، نتیجه‌گیری ارائه خواهد شد.

۲. مروری بر پیشینه پژوهش

موضوع اصلی در کاوش متن، یافتن اسناد مرتبط از میان حجم عظیمی از اسناد است (Saracoglu, Tutuncu, and Allahverdi 2008). دو رویکرد پایه برای جست‌وجوی اسناد مشابه وجود دارد. رویکرد اول استخراج کلیدواژه‌ها از سند (رویکرد مبتنی بر کلیدواژه) (Weng and Lin 2003) و دیگری رویکرد مبتنی بر استفاده از تمامی کلمات سند است. فرایند کشف دانش از پایگاه داده‌ها ضمن این که سبب طبقه‌بندی معتبر، به‌روز و قابل‌استفاده از داده‌ها می‌شود، می‌تواند الگوهای قابل فهمی از داده‌ها ارائه دهد (Fayyad 1996). در متن کاوی به‌طور کلی، استخراج ویژگی تأیید شده است (Gunal et al. 2006). انتخاب ویژگی (Feng et al. 2012) روش طبقه‌بندی (Wu and Li 2013) و پیش‌پردازش (Gunal et al. 2006) تأثیر قابل توجهی بر موفقیت فرایندهای طبقه‌بندی متن داشته است. عملکرد طبقه‌بندی متن از

طریق یک اصطلاح‌نامه مبتنی بر پیکره و وردنت^۱، با به کارگیری الگوریتم نزدیک‌ترین همسایگی و شبکه عصبی پسانتشار (BPNN)^۲ الگوریتم را بهبود دادند (Jiang et al. 2012). الگوریتم K-NN برای طبقه‌بندی متن با ترکیب آن با یک الگوریتم خوشه‌بندی مورد استفاده قرار می‌گیرد. بیزین^۳ ساده، الگوریتمی دیگر است که برای طبقه‌بندی متن موفق بوده است (Chen et al. 2009). برای مثال، مراحل فرایند متن‌کاوی در اخبار و اطلاعات در جدول ۱ نشان داده شده است. در این جدول نوآوری مورد نیاز در جنبه‌های مهم انتخاب ویژگی، کاهش ویژگی و بازنمایی ویژگی‌های بسیار از آثار بررسی شده است.

جدول ۱. مقایسه داده‌های ورودی برای سیستم‌های مختلف

| نویسنده | انواع متون | منبع متن | تعداد مورد بررسی | بدون ساختار | پیش برنامهریزی شده |
|---|---------------------|--|------------------|-------------|--------------------------|
| Tetlock et al. (2008) | اخبار مالی | Wall Street Journal, Dow Jones News Service از بانک اطلاعاتی اخبار در Factiva | ۳۵۰,۰۰۰ متن | بله | خیر |
| Mahajan et al. (2008) | اخبار مالی | اشاره نشده | ۷۰۰ مقاله خبری | بله | خیر |
| Butler and Kešelj (2009) | گزارش‌ها سالانه | وبسایت شرکت | اشاره نشده | بله | بله |
| Schumaker and Chen (2009) | اخبار مالی | Yahoo Finance | ۲,۸۰۰ | بله | گزارش‌های سالانه شرکت |
| Li (2010) | بایگانی‌های شرکت | بحث و تجزیه و تحلیل بخش مدیریت 10-K and 10-Q بایگانی وبسایت SEC Edgar | ۱۳ میلیون بیانیه | بله | خیر |
| Huang, Liao, Yang, Chang, and Luo (2010) and Huang, Chuang, et al. (2010) | اخبار مالی | روزنامه الکترونیکی در تایوان | ۱۲,۸۳۰ سرفصل | بله | خیر |
| Bollen and Huina (2011) | تویتهای | تویتر | ۹,۸۵۳,۴۹۸ | بله | خیر |
| Vu et al. (2012) | تویتهای | تویتر | ۵,۰۰۱,۴۶۰ | بله | خیر |

1. WordNet

2. Back Propagation Neural Network

3. Bayes' theorem

| نویسنده | انواع متون | منبع متن | تعداد مورد بررسی | بدون ساختار | پیش برنامه‌ریزی شده |
|--------------------------|------------------------------|---|-------------------------|-------------|---------------------|
| Schumaker et al. (2012) | اخبار مالی | Yahoo Finance | ۲,۸۰۲ | بله | خیر |
| Lugmayr and Gossen(2012) | اخبار کارگزاری | کارگزاری‌ها | اشاره نشده | بله | خیر |
| Yu, Duan, et al. (2013) | رسانه‌های اجتماعی متعارف | وبلاگ‌ها، فروم‌ها، اخبار و شبکه‌های اجتماعی | ۵۲,۷۴۶ پیام | بله | خیر |
| Hagenau et al. (2013) | اطلاعه‌های شرکت و اخبار مالی | DGAP, EuroAdhoc | ۳,۴۷۸ و ۱۰,۸۷۰ به ترتیب | بله | خیر |
| Jin et al. (2013) | اخبار عمومی | Bloomberg | ۳۶۱,۷۸۲ | بله | خیر |
| Chatrath et al. (2014) | اخبار اقتصاد کلان | Bloomberg | اشاره نشده | خیر | بله |

بنابراین، کشف زمینه‌های متفاوت از نظر انواع بازار و انواع متن ورودی برای سیستم‌ها بسیار حائز اهمیت است.

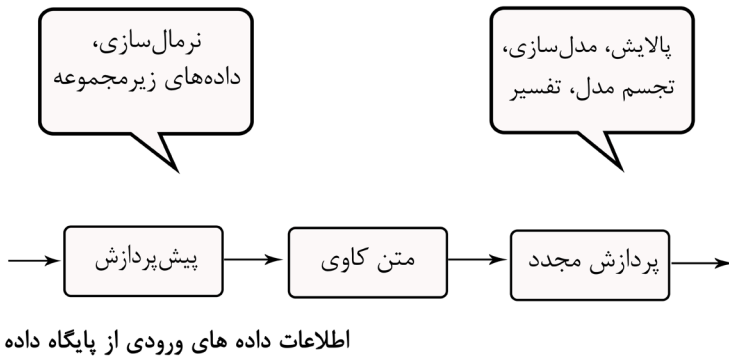
۳. ارتباط متن کاوی و دیگر دانش‌ها

۳-۱. کشف دانش و ارتباط آن با متن کاوی

کشف دانش در پایگاه داده‌ها (KDD)^۱ در اوایل دهه ۸۰ در مراجعه به مفهوم کلی، سطح بالا و به دنبال جست‌وجوی دانش در اطلاعات شکل گرفته است و هدف آن کشف ارتباط و نظم بین اطلاعات قابل مشاهده است. گاهی داده کاوی شامل همه ابعاد فرایند کشف دانش است و در بعضی موارد نیز داده کاوی به عنوان بخشی از فرایندهای KDD در نظر گرفته می‌شود و فاز مدل کردن را توصیف می‌کند. در نهایت، KDD فرایند یافتن اطلاعات و الگوهای مفید از داده را گویند و داده کاوی بهره‌گیری از الگوریتم‌هایی برای یافتن اطلاعات مفید و الگوها در فرایند KDD است. تعاریف مختلفی برای کشف دانش در پایگاه داده وجود دارد؛ مثلاً بیان شده است که KDD فرایند شناسایی الگوهای قابل

1. Knowledge Data Discovery

فهم، مفید، جدید و معتبر در داده است. در واقع، هدف پیدا کردن الگوها و روابط پنهان در این داده‌هاست. از جمله خصوصیتی که برای اندازه‌گیری کیفیت الگوهای پیداشده در داده می‌توان استفاده کرد، عبارت‌اند از: قابلیت فهم انسان، اعتبارسنجی با معیارهای آماری، تازگی و مفیدبودن. کشف دانش در پایگاه داده را می‌توان به‌عنوان یک فرایند که به‌وسیله چندین گام پردازش کردن تعریف می‌شود، در نظر گرفت. این گام‌ها به‌منظور استخراج الگوهای مفید باید بر روی مجموعه داده‌ای اعمال شوند. طبق نظرات قبلی گام‌ها را می‌توان به‌صورت زیر بیان کرد: (۱) درک کردن کسب و کار (۲) درک کردن داده (۳) آماده‌سازی داده (۴) مدل کردن (۵) ارزیابی (۶) گسترش. مرحله پیش‌پردازش غالباً یکی از مراحل زمان‌بر و در عین حال، بسیار مهم در کسب نتیجه مطلوب است؛ به‌ویژه این که در متن کاوی، نیاز به متدهای پیش‌پردازش خاصی برای تبدیل داده متنی به فرامتی مناسب برای الگوریتم‌های داده کاوی داریم.



شکل ۱. ارتباط کشف دانش از پایگاه داده و متن کاوی

۳-۲. تفاوت متن کاوی و داده کاوی

با توجه به رشد و توسعه روزافزون فناوری، اطلاعات به‌صورت گسترده و با سرعت بالا منتشر می‌شود. در نتیجه، یکی از زمینه‌های تحقیقاتی مهم، ذخیره داده‌ها و به‌دست آوردن اطلاعات سودمند از آن‌هاست. داده کاوی برای این منظور به‌وجود آمد و می‌توان گفت که مقدار زیادی از دانش را پردازش کرده و آن‌ها را به اطلاعات کاربردی تبدیل می‌کند و در صورتی که داده‌های مورد پردازش به‌صورت متن و بدون ساختار یا نیمه‌ساختارمند باشند، این فرایند متن کاوی نامیده

می‌شود (Weng and Lin 2003؛ Saracoglu, Tutuncu, and Allahverdi 2008). متن کاوی مشابه داده کاوی است (Berry and Linoff 2004)، با این تفاوت که ابزارهای داده کاوی برای مدیریت داده‌های ساختارمند از پایگاه داده‌ها طراحی شده‌اند (Elmasri and Navathe 2000). متن کاوی می‌تواند با مجموعه داده‌های بدون ساختار یا نیمه‌ساختارمند مانند نامه‌های الکترونیکی، اسناد تمام‌متنی و پرونده‌های وب کار کند. در نتیجه، متن کاوی راه‌حل بهتری برای شرکت‌هاست. با این حال، تا امروز، بیشتر تلاش‌های تحقیق و توسعه روی داده کاوی با استفاده از داده‌های ساختارمند متمرکز بوده‌اند (Weng and Lin 2003؛ Saracoglu, Tutuncu, and Allahverdi 2008؛ Gupta, and Lehal 2009).

جدول ۲. ارتباط داده کاوی و متن کاوی

| کشف سازوکار مشخص | جست‌وجوی هدف مشخص | |
|------------------|-------------------|-----------------------------|
| داده کاوی | بازیابی داده‌ها | داده‌های ساخت یافته |
| متن کاوی | بازیابی اطلاعات | داده‌های بدون ساختار - متنی |

۳-۳. تفاوت متن کاوی و وب کاوی

بر این اساس، متن کاوی با جست‌وجو در وب نیز متفاوت است. در وب کاوی، کاربر به‌طور معمول به دنبال چیزی است که در حال حاضر شناخته شده است و توسط شخصی دیگر نوشته شده است و مسئله صرفاً کنار گذاشتن تمامی موارد نامربوط به نیازها و یافتن اطلاعات مرتبط است. در متن کاوی، هدف کشف اطلاعات ناشناخته است، یعنی چیزی که هنوز کسی آن را نمی‌داند و نمی‌تواند نوشته شده باشد (Gupta, and Lehal 2009).

۴. متن کاوی و جریان کار در متن کاوی

متن کاوی یا کشف دانش از متن برای اولین بار برای استخراج الگوهای متنی بیان شد. می‌توان گفت که متن کاوی از تکنیک‌های بازیابی اطلاعات، استخراج اطلاعات، همچنین پردازش زبان طبیعی استفاده می‌کند و آن‌ها را به الگوریتم‌ها و متدهای KDD، داده کاوی، یادگیری ماشین و آماری مرتبط می‌کند. با توجه به ناحیه‌های تحقیق گوناگون، برای هر یک از آن‌ها می‌توان تعاریف مختلفی از متن کاوی در نظر گرفت. در ادامه، برخی از این تعاریف بیان می‌شوند:

متن کاوی به معنای استخراج اطلاعات: در این تعریف متن کاوی متناظر با استخراج اطلاعات در نظر گرفته می‌شود (استخراج واقعیت‌ها از متن).

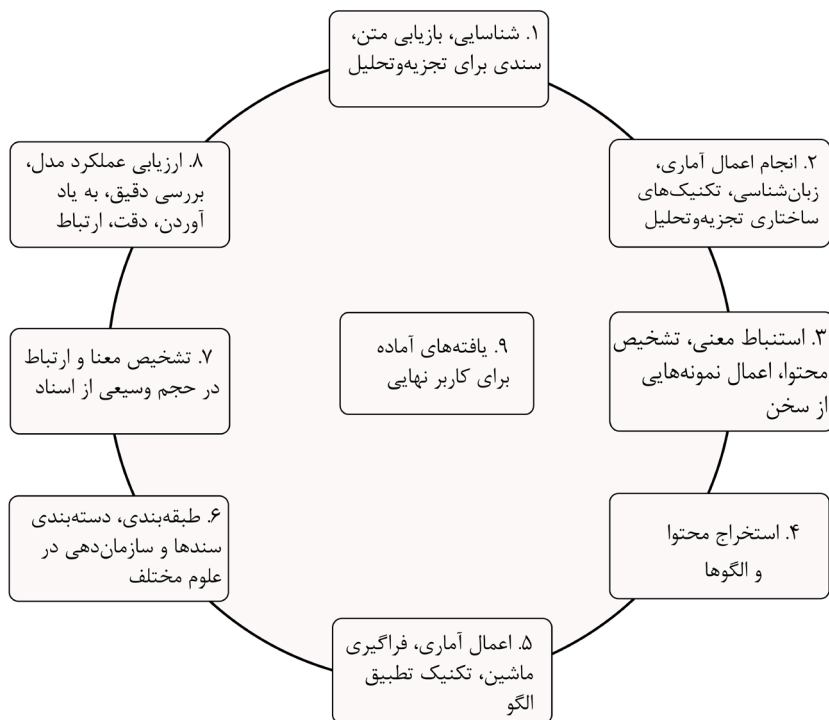
متن کاوی به معنای کشف داده متنی: متن کاوی را می‌توان به‌عنوان متدها و الگوریتم‌هایی از فیلدهای یادگیری ماشین و آماری برای متن‌ها با هدف پیدا کردن الگوهای مفید در نظر گرفت. برای این هدف پیش‌پردازش کردن متون ضروری است. در بسیاری از روش‌ها، متدهای استخراج اطلاعات، پردازش کردن زبان طبیعی یا برخی پیش‌پردازش‌های ساده برای استخراج داده از متون استفاده می‌شود. سپس، می‌توان الگوریتم‌های داده کاوی را بر روی داده‌های استخراج‌شده اعمال کرد.

۴-۱. مزایای متن کاوی

از مزایای متن کاوی می‌توان به مواردی مانند کمک به استخراج اطلاعات مفید از انبوهی از داده‌ها در زمان کم و به‌طور کارآمد و کمک در پیش‌بینی جنبه‌های آینده بر اساس مشاهدات و آمار ارائه‌شده اشاره نمود. (Hashimi, Hafez, and Mathkour (2015) برای متن کاوی زیر را برشمرده‌اند:

- ◇ کمک در پیش‌بینی جنبه‌های آینده بر اساس مشاهدات و آمار ارائه‌شده
- ◇ کمک به ایجاد و ساخت الگو از داده‌های ارائه‌شده که به ما درباره افزایش یا کاهش گرایش‌ها مثلاً در تجارت یا اقتصاد می‌گوید.
- ◇ کمک به نهادهای امنیتی با نظارت و تجزیه و تحلیل داده‌های متنی جمع‌آوری‌شده از منابع اینترنتی مانند وبلاگ‌ها
- ◇ بهبود کاربرد علم پزشکی از پایگاه داده‌های پزشکی موجود با استفاده از روش‌های متن کاوی
- ◇ پیشرفته‌تر کردن تجزیه و تحلیل، ذخیره‌سازی و دسترسی به اطلاعات در وبسایت‌ها و موتورهای جست‌وجوی مختلف به‌منظور کارآمدتر و دقیق‌تر کردن فرایند جست‌وجو
- ◇ کمک به مطالعه توزیع فراوانی کلمه با استفاده از تجزیه و تحلیل لغوی و تشخیص الگو و نویسنده اثر.

کلیه مراحل بیان شده جریان کار عمومی در متن کاوی است که در بلوک دیاگرام شکل ۲ نشان داده شده است.



شکل ۲. کلیه مراحل جریان کار عمومی در متن کاوی

۵. مراحل متن کاوی

فرایند متن کاوی شامل مراحل اصلی پیش‌پردازش، استخراج ویژگی و انتخاب ویژگی است. مراحل کلی فرایند متن کاوی در شکل ۳ نشان داده شده است. ابتدا فرایند پیش‌پردازش روی متن مورد نظر انجام می‌شود و پس از آن عملیات استخراج ویژگی و انتخاب ویژگی‌ها روی آن انجام می‌گیرد. این داده‌ها سپس، با استفاده از الگوریتم‌های مخصوص و الگوهای موجود شناسایی شده و جهت ارزیابی^۱ یا تفسیر^۲ به خروجی فرستاده می‌شود. توضیحات بیشتر در ادامه آمده است.

1. evaluation

2. interpretation



شکل ۳. مراحل کلی فرایند متن کاوی (Hashimi, Hafez, and Mathkour (2015)

۱-۵. پیش‌پردازش

برای کاوش کردن حجم قابل توجهی از اسناد ضروری است که اسناد، پیش‌پردازش شوند و اطلاعات در یک ساختار داده‌ای مناسب برای پردازش‌های بعدی ذخیره گردد. زمانی که داده‌های ورودی در دسترس است باید آن‌ها را برای ورود به الگوریتم‌های یادگیری ماشین آماده کنیم. این مرحله برای داده‌های متنی به این معناست که آن‌ها را از حالت غیرساخت یافته به فرمت ساختاریافته و قابل تشخیص برای ماشین تبدیل کنیم. هدف پیش‌پردازش کاهش ابعاد فضای نمایش لغات موجود در سند بوده و معمولاً شامل وظایف زیر است (Gupta, and Lehal 2009):

- ◇ حذف ایست‌واژه‌ها (کلماتی که در اکثر متون یافت می‌شوند، اما دارای اهمیت معنایی خاصی نبوده و جزو کلیدواژه‌ها به حساب نمی‌آیند).
- ◇ یکسان‌سازی تمامی حروف به یک نوع (از نظر بزرگی و کوچکی حروف)
- ◇ ریشه‌یابی لغات: یکسان در نظر گرفتن کلمات مشابه از نظر نحوی مانند حالت جمع، تغییرات کلامی و ... به منظور به دست آوردن ریشه هر کلمه که بر معنای آن تأکید می‌کند.

برای تعریف رسمی‌تر الگوریتم‌ها برخی تعاریف لازم را بیان می‌کنیم: مجموعه

اسناد با D نمایش داده می‌شود. T نشان‌دهندهٔ دیکشنری است. $T = \{t_1, t_2 \dots t_m\}$. فرکانس ترم $t \in T$ در سند $d \in D$ به صورت $tf(d, t)$ نمایش داده می‌شود. بردار ترم t به صورت $t_x = (tf(d, t_1) \dots tf(d, t_m))$ نمایش داده می‌شود. مرکز مجموعهٔ X از بردارهای ترم به صورت مقدار میانگین بردارهای ترم مربوط تعریف می‌شود:

$$(t_x := \frac{1}{|X|} \sum_{t \in X} t_d) \quad (1)$$

همچنین، می‌توان tf را بر روی زیرمجموعه‌ای از ترم‌ها اعمال کرد. اگر T' زیرمجموعه

T باشد دارای

$$tf(d, T') := \sum_{t \in T'} tf(d, t) \quad (2)$$

داشتن تعداد محدودی از ویژگی‌ها مسئلهٔ بسیار بااهمیتی است. افزایش تعداد ویژگی‌ها که ممکن است به سادگی در طول مرحلهٔ انتخاب ویژگی اتفاق بیفتد، می‌تواند باعث تبدیل شدن مسئلهٔ متن کاوی به یک مسئلهٔ غیرقابل حل برای تمام الگوریتم‌های یادگیری ماشین بشود (Pestov 2013). برای کاهش دادن سایز دیکشنری و ابعاد توصیف اسناد یک مجموعه می‌توان از روش‌های فیلترینگ و ریشه‌یابی استفاده کرد. روش‌های فیلترینگ، کلمات را از دیکشنری و بنابراین از اسناد حذف می‌کنند. از جملهٔ این روش‌ها می‌توان به $stop\ word\ filtering$ و حذف $stop\ word$ ها اشاره نمود. برای کاهش دادن تعداد کلمات دیکشنری می‌توان از روش‌های انتخاب ترم نیز استفاده نمود. در روش‌های انتخاب ترم تنها کلمات انتخاب شده برای توصیف کردن اسناد استفاده می‌شوند. یک روش برای انتخاب کلمات، استخراج کلمات بر اساس درجهٔ خلوص آنهاست. برای هر کلمه t در دیکشنری درجهٔ خلوص آن به صورت زیر تعریف می‌شود:

$$W(t) = 1 + \frac{1}{\log_2 |D|} \sum_{d \in D} P(d, t) \log_2 P(d, t), P(d, t) = \frac{tf(d, t)}{\sum_{l=1}^n tf(d_l, t)} \quad (3)$$

درجهٔ خلوص نشان‌دهندهٔ این است که یک کلمه چقدر اسناد را به خوبی توسط کلمهٔ جست‌وجو جدا می‌کند. اگر کلمه در تعداد زیادی از اسناد رخ داده باشد، درجهٔ خلوص کمی دارد. روش‌های ریشه‌یابی سعی می‌کنند فرم‌های اولیهٔ کلمات را بسازند. مثلاً حذف کردن علامت جمع (s) از اسم‌ها یا ing از افعال و ... بعد از فرایند ریشه‌یابی،

هر کلمه توسط ریشه آن کلمه نمایش داده می‌شود. در واقع، در این جا کلماتی که ریشه مشترک دارند، به ریشه خودشان تبدیل می‌شوند.

جدول ۳. پیش‌پردازش: انتخاب ویژگی، کاهش ابعاد و بازنمایش ویژگی

| نویسنده | انتخاب ویژگی | کاهش ابعاد | بازنمایش ویژگی |
|---|---|---|---------------------------------|
| Tetlock et al. (2008) | Bag-of-words برای لغات منفی | لغتنامه از پیش تعریف شده، فرهنگ لغت روان‌شناسی | فراوانی تقسیم بر تعداد کل کلمات |
| Mahajan et al. (2008) | Latent Dirichlet Allocation (LDA) | استخراج بیست و پنج مبحث | Binary |
| Butler and Kešelj (2009) | Character n-Grams, three readability scores عملکرد سال گذشته | حداقل اتفاق در هر سند | فراوانی n-gram در یک پروفایل |
| Schumaker and Chen (2009) | Bag of words, noun phrases, named entities | حداقل اتفاق در هر سند | Binary |
| Li (2010) | Bag of words لحن و محتوایی | لغتنامه از پیش تعریف شده | Binary, Dictionary value |
| Huang, Liao, Yang, Chang, and Luo (2010) and Huang, Chuang, et al. (2010) | واژگان هم‌زمان، دستور جفت | جایگزینی مترادف‌ها | شاخص وزن‌دار |
| Groth and Muntermann (2011) | Bag-of-words | روش نمره‌دهی ویژگی با استفاده از Information Gain و معیار مجذور کای | TF-IDF |
| Bollen and Huina (2011) | By OpinionFinder | By OpinionFinder | By OpinionFinder |
| Vu et al. (2012) | تعداد کل جملات مثبت یا منفی تویتر | شناسایی نام‌های موجود | Neg_Pos and Bullish_Bearish |
| Schumaker et al. (2012) | OpinionFinder overall tone and polarity | حداقل اتفاق در هر سند | Binary |
| Lugmayr and Gossen(2012) | Bag-of-words | ریشه‌یابی | مقادیر احساسات |
| Yu, Duan, et al. (2013) | Bag-of-words | اشاره نشده | Binary Hagenau |

| نویسنده | انتخاب ویژگی | کاهش ابعاد | بازنمایش ویژگی |
|------------------------|---|---|---------------------|
| Hagenau et al. (2013) | Bag-of-words, noun phrases, wordcombinations, n-grams | Frequency for news, Chi 2 –approach and bi-normal separation (BNS) for exogenous-feedback-based feature selection, dictionary | TF-IDF |
| Jin et al. (2013) | Latent Dirichlet Allocation (LDA) | استخراج موضوع | توزیع هر مقاله |
| Chatrath et al. (2014) | داده‌های ساخت یافته | داده‌های ساخت یافته | داده‌های ساخت یافته |

بعد از انتخاب حداقل تعداد ویژگی‌ها، لازم است آن‌ها را با مقادیر عددی نمایش دهیم تا بتوان از آن‌ها در الگوریتم‌های یادگیری ماشین استفاده کرد. به همین منظور، در ستون مربوط به بازنمایش ویژگی در جدول ۳، روش این کار را برای تمام مقالات بررسی شده مرور کرده‌ایم. مقادیر عددی اختصاص داده شده مانند نمره یا امتیاز عمل می‌کنند. پنج روش بسیار متداول آن عبارت‌اند از: اطلاعات به دست آمده^۱ (IG)، آماره مربع کای^۲ (CHI)، نوسانات سند^۳ (DF)، دقت متوازن^۴ (Acc2) و نوسان معکوس فراوانی سند^۵ (TF-IDF). مقایسه‌ای میان این روش‌ها را می‌توان در پژوهش Tasci و Gungor (2013) مشاهده کرد. پایه‌ای‌ترین آن‌ها روش باینری است که در آن با اختصاص دو مقدار ۱ و ۰ با حضور یا عدم حضور یک ویژگی بررسی می‌شود (Schumaker et al 2012). روش رایج بعدی اصطلاحاً TF-IDF نام دارد (Hegna and Murtomaa 2003) ارزش TF-IDF متناسب با تعداد دفعاتی که یک کلمه در اسناد ظاهر می‌شود، افزایش می‌یابد، اما نسبت به نوسانات واژه در مجموعه سند خنثی است تا بتواند تعادل را برای کلمات برقرار کند. روش‌های رایج و مشابه دیگری نیز وجود دارد. به عنوان مثال TF-CDF، که از روش CF توسعه یافته است، ادعا می‌کند که در عمل می‌تواند کارایی بیشتری نسبت به TF-IDF داشته باشد.

1. information gain

2. Chi-square statistics

3. document frequency

4. accuracy balanced

5. term frequency-inverse document frequency

۵-۱-۱. پیش‌پردازش زبان‌شناختی

گاهی اوقات ممکن است از پیش‌پردازش‌های زبان‌شناختی نیز برای افزایش اطلاعات قابل دسترس درباره‌ی ترم‌ها استفاده شود. برای این منظور روش‌های زیر اعمال می‌شود:

برچسب‌گذاری نحوی: برای هر ترم مشخص می‌کند که اسم، فعل، صفت و ... است. اگرچه تعداد زیادی معتقد به این نیستند که این کار جزئی از متن‌کاوی است، ولی در (Witten 2004)، برای مثال سیستمی به نام GATE در دانشگاه شفیلد، در یک کتابخانه دیجیتال به این قصد جاگذاری شده است. GATE شامل ابزاری برای برچسب‌زدن بر جملات است. برای مثال، این سیستم می‌تواند در داخل یک متن، نام موقعیت‌های جغرافیایی، نام اشخاص و چیزهایی شبیه به این را بیابد. این سیستم بیشتر شامل استخراج اطلاعات است تا استخراج دانش. ^۱ POS اغلب نقش بزرگی را در پردازش زبان‌های طبیعی بازی می‌کند. در حقیقت، این اولین قدم در پردازش زبان طبیعی است و پردازش زبان طبیعی یکی از پایه‌های متن‌کاوی است.

چانک‌کردن متن: هدف، گروه‌بندی کردن کلمات مجاور در یک جمله است.

رفع ابهام معنای کلمه: در این جا سعی می‌شود که ابهامات در معنای یک کلمه یا عبارت رفع شود، مثل زمانی که کلماتی دارای چندین معنای متفاوت هستند. بنابراین، به‌جای ترم‌ها، معناها می‌توانند در نمایش فضای بردار ذخیره شوند. این باعث بزرگ‌تر شدن دیکشنری می‌شود، اما همچنین موجب می‌شود که معنای یک ترم در نمایش در نظر گرفته شود.

۵-۲. تولید و استخراج ویژگی

اگرچه برنامه‌های کاربردی زیادی در زمینه بازیابی اطلاعات مانند پالایش و جست‌وجوی اطلاعات مرتبط می‌توانند از تحقیقات در زمینه رده‌بندی متن سود ببرند، مشکل اصلی رده‌بندی متن، ابعاد بالای فضای ویژگی با توجه به تعداد زیاد لغات است. این مشکل ممکن است موجب افزایش پیچیدگی محاسباتی روش‌های یادگیری ماشین برای رده‌بندی متن شده و با توجه به کلمات نامرتبط یا زائد موجب ناکارآمدی نتایج

حاصل از دقت کم بشود. به عنوان راه‌حلی برای این مشکل از روش‌های استخراج ویژگی و انتخاب ویژگی استفاده می‌شود.

۳-۵. انتخاب ویژگی

انتخاب ویژگی فرایندی است که زیرمجموعه‌ای از ویژگی‌های اصلی را با توجه به برخی از معیارها یا اهمیت ویژگی انتخاب می‌کند. الگوریتم‌های انتخاب ویژگی به دو دسته تقسیم می‌شوند:

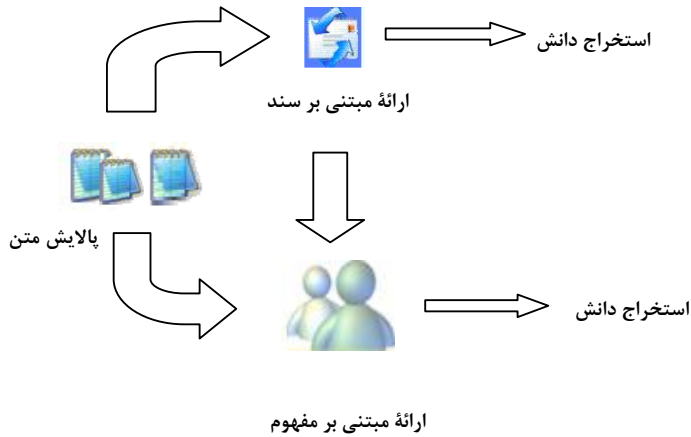
الگوریتم‌های رتبه‌بندی ویژگی: این الگوریتم‌ها ویژگی‌هایی را که به‌تنهایی برای طبقه‌بندی بسیار مرتبط هستند، بدون در نظر گرفتن تعامل ویژگی‌ها انتخاب می‌کنند. این موضوع، الگوریتم‌های FR را ساده کرده و از نظر محاسباتی کارآمدتر از الگوریتم‌های انتخاب زیرمجموعه ویژگی می‌سازد و بنابراین، یک انتخاب ارجح برای رده‌بندی متن می‌باشد. تفکیک دو گانه نرمال و IG نمونه‌هایی از الگوریتم‌های FR هستند. با این حال، الگوریتم‌های FR مجموعه‌ای از ویژگی‌ها یا کلمات بسیار مرتبط را در خروجی ایجاد می‌کنند که احتمالاً می‌تواند زائد بوده و بدین ترتیب منجر به کاهش عملکرد یک طبقه‌بندی شود.

الگوریتم‌های انتخاب زیرمجموعه ویژگی (FSS): این الگوریتم‌ها تعامل بین ویژگی‌ها را در نظر می‌گیرند و در عین حال، از نظر محاسباتی پیچیده هستند (Javed, Maruf, and Babri 2015). یک عنصر کلیدی فرایند متن کاوی، ارتباط اطلاعات استخراج شده به همدیگر به منظور تشکیل حقایق یا فرضیات جدید برای استفاده‌های بعدی توسط ابزارهای متداول است.

۶. فازهای اصلی فرایند متن کاوی

اولین فاز، پیش‌پردازش مستندات است. خروجی این فاز می‌تواند دو شکل مختلف داشته باشد: (۱) مبتنی بر سند، و (۲) مبتنی بر مفهوم. در فرمت نمایش مبتنی بر سند آنچه مهم است، نحوه نمایش بهتر مستندات است؛ مثلاً تبدیل اسناد به یک فرمت میانی و نیمه‌ساخت یافته، یا به کاربردن یک ایندکس بر روی آن‌ها یا هر نوع نمایش دیگری که کار کردن با اسناد را کارآتر می‌کند. در نوع دوم، نمایش اسناد بهبود بخشیده می‌شود و

مفاهیم و معانی موجود در سند و نیز ارتباط میان آن‌ها و هر نوع اطلاعات مفهومی دیگری که قابل استخراج است، از متن استخراج می‌شود. در این نوع نمایش، دیگر با مستندات به‌عنوان یک موجودیت مواجه نیستیم، بلکه با مفاهیمی که از این مستندات استخراج شده‌اند، روبه‌رو هستیم. قدم بعدی استخراج دانش از این فرم‌های میانی نمایش اسناد است. بر اساس نحوه نمایش یک سند، روش استخراج دانش از یک سند متفاوت است. نمایش مبتنی بر سند، برای گروه‌بندی، طبقه‌بندی، تجسم‌سازی و نظایر این‌ها استفاده می‌شود، در حالی که نمایش مبتنی بر مفهوم برای یافتن روابط میان مفاهیم، ساختن اتوماتیک تزاروس و آنتولوژی و نظایر آن به کار می‌رود که در شکل ۴ نمایش داده شده است.



شکل ۴. فرایند متن کاوی



شکل ۵. مدیریت مناسب داده‌ها (هژیر ۱۳۹۳)

برای رسیدن به یک سیستم اطلاعاتی مناسب، داده‌ها می‌بایست به صورتی منطقی طبقه‌بندی و ذخیره شوند تا استفاده از آن‌ها ساده‌تر بوده، با کارایی بیشتری تحلیل شوند و سریع‌تر مورد استفاده قرار گیرند و در نتیجه، مدیریت بهتری بر آن‌ها اعمال شود.

۶-۱. استخراج اطلاعات

نقطه شروع برای رایانه‌ها به‌منظور تجزیه و تحلیل متن بدون ساختار، استفاده از استخراج اطلاعات است. نرم‌افزار استخراج اطلاعات، عبارات کلیدی و روابط درون متن را شناسایی می‌کند و این کار را با جست‌وجوی دنباله‌های از پیش تعریف‌شده در متن طی فرایندی، که تطبیق الگو نام دارد، انجام می‌دهد. این نرم‌افزار به روابط بین تمام افراد، مکان‌ها و زمان‌های شناسایی شده برای ارائه به کاربر با اطلاعات بامعنا پی می‌برد. این فناوری می‌تواند در رابطه با متون حجیم، بسیار کاربردی باشد. داده کاوی سنتی فرض می‌کند که داده‌های در حال کاوش در قالب پایگاه داده‌های رابطه‌ای هستند، در حالی که این‌طور نبوده و با کمک این روش، اطلاعاتی که هیچ‌گونه ساختاری ندارند، تبدیل به اطلاعاتی می‌شوند که دارای ساختار بوده و می‌توانند به‌صورت بهتری مورد استفاده واحد کشف دانش قرار بگیرند (Gupta and Lehal 2009).

۶-۱-۱. رده‌بندی برای استخراج اطلاعات

استخراج اشیاء بر اساس درک پیغام فرمول‌بندی می‌شوند. کلماتی که شیء با آن‌ها آغاز می‌شود، برچسب B، کلماتی که داخل شیء می‌آیند، برچسب A، و کلمات خارج از شیء برچسب O می‌گیرند. برای مثال، فرض کنید یکی از اطلاعات استخراج‌شده از اسناد، نام افراد جدیدالورود به شرکت باشد که برابر با (John J. Donner, Jr.) است. در این صورت داریم:

$$(۴) \quad \text{"by (O) John (B) J. (I) Donner (I) Jr. (I) the (O)"}$$

در این جا مشکل رده‌بندی ترتیبی برای برچسب‌های هر کلمه، با کلمات مجاور به‌عنوان بردار ویژگی ورودی وجود دارد. یک روش متداول برای نمایش بردار ویژگی، نمایش آن به‌صورت باینری است. هر جزء ویژگی می‌تواند به‌عنوان یک آزمون در نظر گرفته شود که اثبات می‌کند آیا یک الگوی خاص در یک موقعیت خاص رخ می‌دهد یا نه. برای مثال، یک جزء ویژگی اگر کلمه قبلی، کلمه "John" است، مقدار ۱ و در غیر

این صورت مقدار ۰ می‌گیرد. علاوه بر تست کردن وجود کلمات خاص می‌توان این را نیز تست کرد که آیا کلمات با حروف بزرگ شروع می‌شوند و پسوند خاصی دارند یا نه. هم‌اکنون می‌توان هر متد رده‌بندی کارایی را برای رده‌بندی کردن برچسب‌های کلمات با استفاده از بردار ویژگی ورودی به کار برد.

۲-۶. ردیابی موضوع

این روش با استفاده از نگهداری پروفایل کاربر و بر اساس موضوعات مورد علاقه انتخاب‌شده توسط او یا پیگیری اسنادی که او مشاهده می‌کند، سایر اسناد مورد علاقه وی را پیش‌بینی می‌کند. یک نمونه از این روش توسط وب‌سایت «یاهو» مورد استفاده قرار گرفته است. این فناوری می‌تواند کاربردهای گوناگونی داشته باشد. به عنوان مثال، می‌تواند یک شرکت را از وجود اطلاعاتی در رابطه با رقبای در اخبار آگاه نماید. همچنین، می‌تواند مورد استفاده پزشکانی قرار گیرد که در جست‌وجوی درمان جدید برای بیماری‌ها هستند یا می‌خواهند در جریان آخرین پیشرفت‌ها قرار گیرند. همچنین، در حوزه آموزش می‌توان از فناوری ردیابی موضوع برای اطمینان از در اختیار داشتن جدیدترین منابع تحقیقاتی مورد علاقه استفاده نمود (Gupta and Lehal 2009).

۳-۶. خلاصه‌سازی

خلاصه‌سازی متن یعنی دریافت یک متن و تولید یا استخراج یک متن دیگر از متن اصلی، به گونه‌ای که متن به دست آمده از متن اصلی کوتاه‌تر باشد، نکات اصلی و مهم آن را دربرداشته باشد، و خوانا بوده و بین جملات آن پیوستگی وجود داشته باشد. این فناوری به منظور تلاش برای فهمیدن این که آیا یک متن طولانی مطابق با نیاز کاربر بوده و ارزش خواندن تمام آن را دارد یا خیر، بسیار مفید است. این سیستم قادر به پردازش و خلاصه‌سازی یک متن بسیار طولانی در زمانی معادل با زمان خواندن تنها یک پاراگراف متن توسط کاربر است. نکته کلیدی خلاصه‌سازی، کاهش طول و جزئیات یک سند با حفظ مفاهیم اصلی و معنای کلی آن است. چالش مطرح در این جا این است که اگرچه رایانه‌ها قادر به شناسایی افراد، مکان‌ها، زمان و ... هستند، اما آموزش نرم‌افزار به منظور تجزیه و تحلیل معانی و تفسیر آن‌ها بسیار پیچیده است. خلاصه‌سازی به دو صورت استخراجی (گزینشی) و چکیده انجام می‌شود. در نوع استخراجی از روش‌های

آماری استفاده شده و متن خلاصه با انتخاب جملاتی از متن اصلی به دست می آید. در خلاصه سازی از نوع چکیده از روش های پردازش زبان طبیعی استفاده می شود و خلاصه متن پس از فهم مطالب موجود در متن اصلی تولید می شود. در خلاصه سازی یک مقدار به صورت درصد به عنوان سطح خلاصه سازی متن توسط کاربر تعیین می شود. فرایند خلاصه سازی خودکار متن طی سه مرحله شامل پیش پردازش، تبدیل ساختار متن به ساختار خلاصه، و تولید متن خلاصه انجام می شود (Gupta and Lehal 2009).

۶-۴. خوشه بندی

روشی است که برای گروه بندی اسناد مشابه مورد استفاده قرار می گیرد. این روش با رده بندی تفاوت دارد و در آن به جای استفاده از موضوعات از پیش تعریف شده، گروه بندی به صورت خودکار و پویا انجام می شود. مزیت آن این است که اسناد می توانند در چند زیرعنوان ظاهر شوند. بنابراین، یک سند مفید هیچ وقت از دست نخواهد رفت. یک الگوریتم خوشه بندی پایه، یک بردار از موضوعات برای هر سند ایجاد می کند و وزن ها را اندازه گیری کرده و تصمیم می گیرد که سند برای کدام موضوع مناسب تر است. خوشه بندی برای اسناد بسیار کاربردی است. در الگوریتم های خوشه بندی مانند میانگین-K، هنگام محاسبه شباهت بین اسناد متنی، نه تنها بردار ویژه مبتنی بر الگوریتم آماری فراوانی لغات در نظر گرفته می شود، بلکه ترکیب درجه ارتباط بین کلمات و همچنین رابطه بین کلیدواژه ها در نظر گرفته می شود. در نتیجه، دقت خوشه بندی متن افزایش می یابد (همان).

۶-۵. ارتباط دهنده مفاهیم

ابزارهای ارتباط دهنده مفاهیم، اسناد مرتبط را با شناسایی مفاهیم معمولاً مشترک به یکدیگر متصل می کنند و به کاربران کمک می کنند تا اطلاعاتی را بیابند که شاید با جست و جوی سنتی قادر به یافتن آن نبودند. این روش، مشاهده و مرور اطلاعات را به جای جست و جوی آن ترویج می دهد. ارتباط مفاهیم، یک مفهوم ارزشمند در متن کاوی است، به خصوص در زمینه پزشکی که در آن تحقیقات زیادی انجام شده است و برای محققان

غیرممکن است که تمامی مطالب موجود را خواننده و آن‌ها را به سایر تحقیقات ارتباط دهند. در حالت ایده‌آل، نرم‌افزار ارتباط‌دهنده مفاهیم می‌تواند پیوند بین بیماری‌ها و درمان‌ها را شناسایی کند، حتی زمانی که انسان به دلیل حجم زیاد اطلاعات در دسترس قادر به انجام این کار نیست (همان).

۶-۶. تصویرسازی اطلاعات

تصویرسازی اطلاعات یا متن کاوی بصری^۱، منابع متنی عظیم را در سلسله‌مراتب تصویری یا نقشه قرار می‌دهد و علاوه بر قابلیت جست‌وجوی ساده، قابلیت مرور را نیز فراهم می‌کند. تصویرسازی اطلاعات هنگامی مفید است که کاربر به محدود کردن طیف گسترده‌ای از اسناد و کشف موضوعات مرتبط نیاز دارد. به‌عنوان مثال، دولت می‌تواند با استفاده از تصویرسازی اطلاعات شبکه‌های تروریستی را شناسایی کرده یا در مورد جنایات به اطلاعاتی دست یابد که پیش از این ارتباطی بین آن‌ها تصور نمی‌شد (همان).

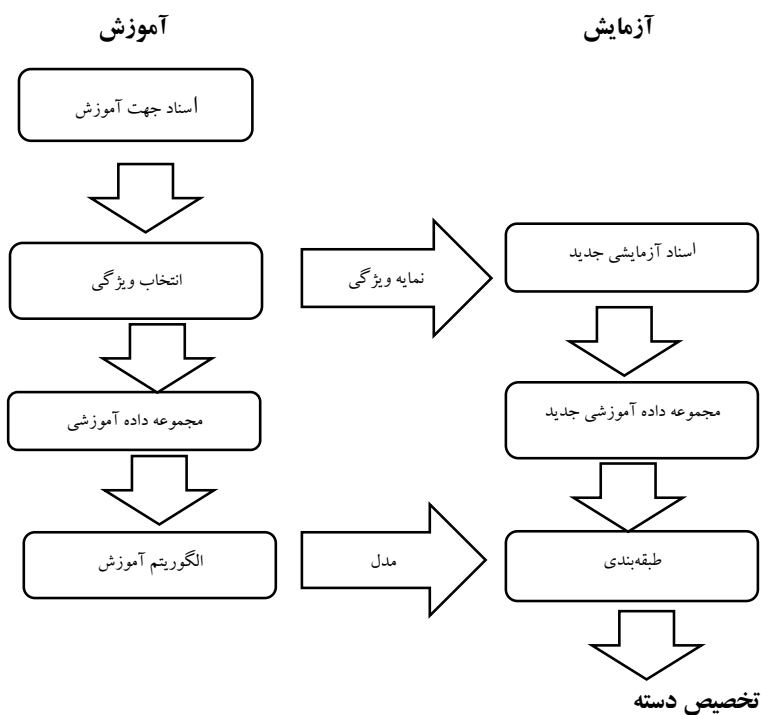
۷. مدل پیشنهادی

رده‌بندی متن، فناوری کلیدی برای سازماندهی داده‌های متنی بوده (Changa, Chena, and Liaub 2008; Ai Zamil and Can 2011) و به‌طوری گسترده در هنگام سازماندهی اسناد دیجیتال مورد استفاده قرار می‌گیرد. با توجه به افزایش تعداد اسناد دیجیتالی، رده‌بندی خودکار متن امروزه بیش از پیش مورد توجه قرار گرفته است. رده‌بندی شامل شناخت موضوع یا موضوعات اصلی یک سند و قرار دادن آن در یک مجموعه شامل تعداد ثابتی از موضوعات از پیش تعریف شده است (Gupta and Changa, Chena, and Liaub 2008; Ai Zamil and Can 2011; Lehal 2009). در رده‌بندی، یک سند به‌صورت کیسه‌ای از کلمات^۲ در نظر گرفته می‌شود. پس از شمارش کلمات ظاهرشده در اسناد، محاسبات خاصی صورت می‌گیرد و موضوعات اصلی که یک سند را پوشش می‌دهند، شناسایی می‌شوند. بلوک دیاگرام شکل ۶، جریان رده‌بندی متن را به‌صورت کلی نشان داده است. در این دیاگرام دو بخش آزمایش و آموزش وجود دارد که در بخش آموزش ویژگی‌هایی از اسناد انتخاب می‌گردد و با توجه به داده‌های آموزشی یک الگوریتم شکل می‌گیرد که

1. visual text mining

2. bag of words

معمولاً از الگوریتم‌های یادگیری ماشین تحت سرپرست استفاده می‌شود. هدف آن‌ها یادگیری طبقه‌بندی از نمونه‌های شناخته‌شده (به اصطلاح اسناد دارای برچسب) و انجام رده‌بندی خودکار نمونه‌های ناشناخته (به اصطلاح اسناد بدون برچسب) است. این موضوع در شکل ۶، نشان داده شده است. بنابراین، طراحی یک الگوریتم انتخاب ویژگی خوب برای رده‌بندی متن، جایی که تعداد زیادی از ویژگی‌ها که نشان‌دهنده کلمات بوده و لغات دارای چالش‌های جدی برای اثربخشی و کارایی طبقه‌بندی هستند، از اهمیت خاصی برخوردار است (Javed, Maruf, and Babri 2015).



شکل ۶. بلوک دیاگرام جریان رده‌بندی متن (Gupta and Lehal 2009)

رده‌بندی اغلب متکی بر یک واژه‌نامه است که در آن موضوعات از قبل تعریف شده و روابط میان کلمات مشخص هستند. ابزارهای رده‌بندی به‌طور معمول از روشی برای رتبه‌بندی اسناد به‌منظور تعیین اسنادی که دارای بیشترین محتوا درباره موضوعی خاص هستند، استفاده می‌کنند. رده‌بندی نیز همانند خلاصه‌سازی می‌تواند به همراه روش ردیابی

موضوع به‌منظور تشخیص ارتباط یک سند با فردی که در جست‌وجوی اطلاعات درباره موضوعی است، مورد استفاده قرار گیرد. هدف از رده‌بندی متون نسبت‌دادن کلاس‌های از پیش تعریف‌شده به اسناد متنی است. مثلاً خبر جدیدی که وارد می‌شود، بگویم متعلق است به کلاس ورزشی یا سیاسی یا هنری. برای رده‌بندی اسناد روش‌های گوناگونی به کار می‌رود. در رده‌بندی یک مجموعه آموزش از اسناد وجود دارد که برای این مجموعه کلاس‌ها مشخص است. با استفاده از این مجموعه مدل رده‌بندی مشخص می‌شود. سپس، با استفاده از آن کلاس‌ها سند جدیدی که وارد می‌شود، مشخص می‌گردد. دو رویکرد پایه برای جست‌وجوی اسناد مشابه وجود دارد. رویکرد اول استخراج کلیدواژه‌ها از سند (رویکرد مبتنی بر کلیدواژه) (Weng and Lin 2003) و دیگری رویکرد مبتنی بر استفاده از تمامی کلمات در سند است. در این روش بردار ویژگی^۱ سند با کمک تمام کلمات موجود در سند تعیین‌شده و شباهت مورد جست‌وجو قرار می‌گیرد. این ویژگی بین تمام لغات و همچنین تمام اسناد با استفاده از مدل فضای بردار^۲ نمایش داده می‌شود. اگرچه روش مبتنی بر کلیدواژه به فرایند تصمیم‌گیری سرعت می‌بخشد، اما تشکیل بردار ویژگی سند با استفاده از تمام کلمات، نتایج جست‌وجو را قطعی‌تر و دقیق‌تر می‌سازد (Saracoglu, Tutuncu, and Allahverdi 2007).

با توجه به مطالب بررسی‌شده جست‌وجوی سند مشابه به‌عنوان بخشی از متن کاوی در نظر گرفته می‌شود و شامل مراحل پیش‌پردازش، رده‌بندی و خوشه‌بندی است. به‌عنوان مثال، یکی از نویسندگان محبوب کتاب‌های کودکان به نام «لایمن فرانک باوم»^۳ مشهور به «ال. فرانک باوم» که خالق اثر «جادوگر شهر» می‌باشد، در سن ۶۳ سالگی درگذشت. وی ۱۹ کتاب درباره «جادوگر شهر» از خود به یادگار گذاشت. اتفاق جالبی که یک سال پس از مرگ وی رخ داد، چاپ اثر جدیدی با نام ایشان بود. بر همین اساس پژوهشگران داده کاوی و متن کاوی کتاب‌های او را به ۵۰۰۰ تکه رده‌بندی کرده و فراوانی کلمات را در هر دسته شمارش کردند. سپس، پنجاه کلمه‌ای را که بیشتر استفاده شده بود، به‌عنوان پرکاربردترین کلمات استخراج کردند.

در نهایت، مقایسه‌ای بین آثار قبلی این نویسنده و اثر منتشرشده جدید صورت گرفت و فراوانی استفاده از کلمات در نوشته‌های فرانک باوم مشخص شد. با توجه به بررسی‌های

1. feature vector

2. Vector Space Model

3. Lyman Frank Baum

صورت گرفته روی متون و کاهش بعدی برای مصورسازی و تحلیل مؤلفه‌های اصلی می‌توان نتیجه گرفت که اسلوب نگارش نویسنده کاملاً متفاوت است. لذا، با توجه به دقت بالای محاسبات، اثر جدید با آثار قبلی نویسنده همخوانی نداشته و مالکیت معنوی آثار ایشان مشخص می‌شود. البته روش‌های هوش مصنوعی زیادی در این مراحل مورد استفاده قرار گرفته‌اند. همچنین، از این موضوع به‌عنوان یکی از عملیات اساسی مدیریت اسناد می‌توان بهره برد. علاوه بر این، یافتن اسناد مرتبط با اسناد موجود از میان حجم عظیمی از اسناد، موضوع مهمی است. این به معنای عدم ارائه اسناد نامرتبط یا کاهش تعداد اسناد نامرتبط تا حد ممکن در نتایج جست‌وجو است. تمامی این مباحث ما را به‌سوی طراحی یک سیستم جست‌وجوی مؤثرتر سوق می‌دهد (Saracoglu, Tutuncu, and Allahverdi 2007).

برای اندازه‌گیری کارایی مدل رده‌بندی، یک مجموعه تست، که مستقل از مجموعه آموزش است در نظر گرفته می‌شود و برچسب‌هایی که برای این اسناد توسط مدل تخمین زده می‌شود با برچسب واقعی اسناد مقایسه می‌شود. نسبت اسنادی که به‌درستی رده‌بندی شده‌اند به تعداد کل اسناد accuracy نامیده می‌شود. سه معیار برای مقایسه رده‌بندی کننده‌ها استفاده می‌شود: (۱) precision: کسری از اسناد بازیابی شده‌ای که مربوط هستند، (۲) recall: نشان‌دهنده کسری از اسناد مربوط بازیابی شده است. این دو معیار به‌صورت زیر تعریف می‌شوند:

$$precision = \frac{\#\{relevant \cap retrieved\}}{\#retrived} \quad (5)$$

$$recall = \frac{\#\{relevant \cap retrieved\}}{\#relevant} \quad (6)$$

بین precision و recall، مصالحه^۱ وجود دارد. به همین دلیل، معیار دیگری به نام F-score که مصالحه‌ای بین هر دو برقرار می‌کند، برای اندازه‌گیری کارایی کل رده‌بندی کننده به کار می‌رود.

$$f = \frac{2}{1/recall + 1/precision} \quad (7)$$

1. trade off

برخی از روش‌های به کار گرفته شده برای رده‌بندی متن مبتنی بر نظریه‌های آماری و یادگیری ماشین عبارت‌اند از: k نزدیک‌ترین همسایه^۱، نیو بیز^۲، ماشین بردار پشتیبان^۳ و شبکه عصبی^۴.

در خصوص مقالات فارسی، هر یک از چالش‌های رسم‌الخط زبان فارسی رایانه‌ای، رفتار متفاوتی از خود نشان می‌دهد و می‌توان آن‌ها را در رده‌بندی متن لحاظ کرد. نتیجه این رفتارها در چندین آثار فارسی به قرار زیر است:

۱. بررسی نحوه استفاده از حروف اضافه در مقالات و آثار قبلی نویسندگان و تطبیق دادن با نمونه جدید؛

۲. تنوع نحوه استفاده از پیشوندها و پسوندها مانند «می»، «ها». موارد فوق به‌طور چسبیده یا جدا از کلمه به کار برده می‌شود؛

۳. به کار بردن «حمزه» به صورت‌های مختلف. جست‌وجو برای کلمات مشابه، با حالت‌های مختلف «حمزه». به عبارت دیگر کاوش کلمه «مسئله» به کاوش برای کلمات «مسئله» و «مسأله» منجر می‌شود. می‌توان با جایگزینی «ی» به جای «ء» نیز دامنه کاوش را وسیع‌تر نمود، مثل «رئیس» و «رئیس»؛

۴. استفاده یا عدم استفاده از «ء» در ترکیب‌های اضافی یا وصفی؛

۵. استفاده از «ا» و «آ» در آثار؛

۶. استفاده از اصطلاح‌نامه^۵ در زبان انگلیسی برای حل مشکل تنوع املائی کلمات. این معضل در زبان‌های دیگر شامل تنوع استفاده از «ی» در کلمات عربی مختوم به «ا»، می‌باشد؛

۷. استفاده از کلمات خارج از زبان فارسی به صورت ترجمه فارسی یا معادل فارسی آن‌ها در مقالات و نوشته‌ها؛

۸. تبدیل کلمات اروپایی به رسم‌الخط فارسی با همان تلفظ اصلی (crosslanguage retrieval): مانند برنامه‌های «Open Sourc» که از کلمه «سورس باز» به جای آن استفاده می‌شود.

1. K-Nearest Neighbor (KNN)

2. naive bayes

3. Support Vector Machine

4. neural network

5. thesaurus

نمونه‌ای از پایگاه داده که با مشاوره انجمن‌ها، بزرگان و فرهنگستان ادب زبان فارسی تشکیل شده، در جدول ۴ نشان داده شده است:

جدول ۴. نمونه‌ای از محتویات پایگاه داده مترادف‌ها

| واژه اصلی | واژه استفاده شده |
|-----------|--|
| موسیقی | موسا |
| امپراتور | امپراطور |
| Ontology | آنتولوژی، انتولوژی، انتالوژی، هستی‌شناسی |
| Computer | کامپیوتر، رایانه |
| Source | منبع، سورس |

۸. یافته‌ها

فنون متن کاوی اشکال متفاوتی دارند و برخی از فنون متناسب با نوع داده‌های متنی برای مشابه‌یابی موضوعیت بیشتری می‌یابد. از میان متن‌های مختلف تنها متنی که روابط بسیار دقیق و معناداری میان آن برقرار است تا حدی که برای محققان متن کاوی جلب توجه کرده، اعجاز عددی الفاظ «قرآن» است که مشابه‌یابی با فنون مختلف متن کاوی به خوبی جواب داده است. یافتن متون مشابه از نظر مفهومی به صورت خودکار یکی از کاربردهای اصلی و مهم متن کاوی در مدیریت و سازماندهی اسناد متنی به شمار می‌رود. هر یک از کارهای تحقیقاتی انجام شده در این زمینه به نوعی با هدف گرفتن چالش‌های مطرح سعی در بهبود بخشی از عملیات این فرایند دارد که منجر به بهبود عملکرد و کارایی کل اثر می‌شود. از چالش‌های موجود در این زمینه می‌توان به موارد زیر اشاره کرد:

- ◇ ابعاد بالای فضای ویژگی با توجه به تعداد زیاد لغات در متن؛
- ◇ چند معنایی لغات موجود در متن و مسئله لغات مترادف؛
- ◇ ارتباط مفهومی میان کلمات موجود در متن؛
- ◇ پراکندگی مفاهیم به خصوص در متون کوتاه؛
- ◇ دقت الگوریتم مشابه‌یابی متون؛
- ◇ سرعت الگوریتم مشابه‌یابی متون.

هر روشی که پاسخ مناسب‌تری برای رسیدگی به چالش‌های مطرح در این حوزه ارائه دهد، بر بهبود عملکرد یافتن متون مشابه تأثیری مثبت خواهد داشت.

با توجه به موارد بیان‌شده و روش‌های متن‌کاوی، رویکردی که مطرح می‌شود برای حفاظت از مالکیت معنوی و فکری در آثار نویسندگان است. در این نظریه با استفاده از علم متن‌کاوی و ابزارهای پیوند مفهومی^۱ می‌توان اسناد مرتبط را از نظر معنایی بررسی کرد و اشتراک بین آن‌ها را به صورت یک قانون کلی، با دقت بالا و به صورت مدل عینی پیاده‌سازی کرد. این امر یکی از مهم‌ترین مواردی است که می‌تواند بر خلاف شیوه‌های سنتی و قدیمی برای حفاظت از اثر نویسندگان بسیار مفید واقع گردد. بدین منظور، می‌توان با بررسی آثار قبلی و قدیمی نویسنده یک مدل مفهومی از آن‌ها استخراج کرد. به عنوان مثال، با استفاده از کلماتی که در شیوه نگارش نویسندگان موجود است و حروف اضافه‌ای که همواره استفاده می‌کنند، یک مدل خاص برای صاحبان اثر ایجاد می‌شود. به این صورت، با استفاده از متن‌کاوی و کشف الگوهای معنادار از متن می‌توان در مورد اثری که نویسنده‌ای مدعی آن است، بررسی انجام داد و صاحب اثر اصلی را تشخیص داد که این امر انقلاب بزرگی در حفظ آثار متنی به وجود می‌آورد.

همچنین، پیوند مفاهیم ارزشمند در متن‌کاوی، به ویژه در حوزه سلامت و زیست‌پزشکی بسیار کاربردی است و در مورد آن پژوهش بسیاری انجام شده است. مطمئناً خواندن حجم زیادی از محتوا و مرتبط ساختن آن‌ها به دیگر پژوهش‌ها برای پژوهشگران غیرممکن است. بنابراین، برنامه‌های پیوند مفاهیم ممکن است پیوند میان بیماری‌ها و درمان‌ها را تشخیص دهد که معمولاً انسان‌ها از عهده آن بر نمی‌آیند. برای نمونه، نرم‌افزارهای متن‌کاوی ممکن است به آسانی پیوند میان عنوان «آ» و «ب» و «پ» و «ت» را که روابط مشهور هستند، تشخیص دهند. ابزارهای متن‌کاوی همچنین قادر به تشخیص پیوند بالقوه میان «آ» و «ت» نیز هستند. با توجه به محدودیت‌های آنی و فیزیکی پژوهشگران انسانی برای بررسی حجم قابل توجه متن‌ها و کشف ارتباط بین آن‌ها، که باعث عدم کشف ارتباط و دسته‌بندی متون می‌شود، نیاز به استفاده از روش‌های متن‌کاوی بسیار ضروری احساس می‌شود.

این است که برای ایجاد شبکه‌های مفهومی، استفاده از داده‌کاوی و فنون متن‌کاوی

1. concept linkage

ضروری می‌باشد. بسیاری از این ابزارها در ایجاد پیوند میان متون، مفاهیم، اصطلاح‌ها و ایجاد شبکه‌ای منسجم از داده‌ها و در نتیجه، کشف اطلاعات و دانش از آن‌ها نقشی مؤثر خواهند داشت؛ به‌ویژه هنگامی که حجم منابع بسیار زیاد است و انسان به‌سختی قادر به طبقه‌بندی و درک ارتباط بین آن‌هاست. ابزار متن‌کاوی، منابع متن‌کاوی و یا برنامه‌های تخصصی متن‌کاوی از ملزومات یک پژوهش جامع در مورد تمام بخش‌های کار می‌باشد. اما، در آینده نیاز است که هر کدام از بخش‌های انتخاب و ویژگی، بازنمایش ویژگی و کاهش ویژگی به شکل تخصصی مورد بررسی قرار گیرد. اما برای بررسی تخصصی‌تر می‌توان به‌صورت خاص منابع متن‌کاوی مثل رسانه‌های اجتماعی، تیتروهای خبری، متن‌های خبری و متون علمی و غیره را مورد بررسی قرار داد. بنابراین، با استفاده از ابزارهایی مانند رایانه و علوم می‌مثل زبان‌شناسی، فلسفه ذهن، فلسفه زبان، هوش مصنوعی، همچنین تکنیک‌های سازماندهی متون و منابع، با استفاده از نظام‌های فهرست‌نویسی، نمایه‌سازی، و طبقه‌بندی و ... علاوه بر این که راه‌حلی برای دسترسی سریع و آسان به اطلاعات و کشف دانش فراهم می‌شود، می‌تواند روشی مؤثر برای حفاظت از مالکیت فکری و معنوی آثار متنی نیز به‌شمار رود.

جدول ۵. مقایسه در زمینه مشابه‌یابی

| موضوعات و مزیت‌ها | نام مقاله |
|---|---|
| پیشنهاد روشی دومرحله‌ای برای رده‌بندی اسنادی که متعلق به چند طبقه هستند با استفاده از خوشه‌بندی فازی و رده‌بندی شباهت فازی. | Saracoglu, Tutuncu, and Allahverdi 2007 |
| ارائه یک روش دومرحله‌ای برای استخراج ویژگی و انتخاب ویژگی به‌منظور بهبود عملکرد رده‌بندی اسناد مشابه با استفاده از رتبه‌بندی به روش IG و استخراج و انتخاب ویژگی با استفاده از الگوریتم ژنتیک (GA) و تجزیه و تحلیل مؤلفه‌های اصلی (PCA) به‌صورت جداگانه. | Uguz 2011 |
| یکپارچه‌سازی وردنت با زنجیره لغوی با استفاده از ساختار سلسله‌مراتبی هستان‌شناسی و ارتباطات برای ارائه یک ارزیابی دقیق‌تر بین لغات برای ابهام‌زدایی مفهوم کلمه و در نتیجه، کاهش ابعاد فضای ویژگی. | Wei et al. 2015 |
| استفاده از تجزیه و تحلیل مدل موضوعی به‌منظور بهبود عملکرد رده‌بندی متون کوتاه. | Vo, and Ock 2015 |
| ارائه یک الگوریتم انتخاب ویژگی دومرحله‌ای برای انتخاب ویژگی در رده‌بندی متون با در نظر گرفتن تعاملات کلمات به‌منظور حذف کلمات زائد. | Javed, Maruf, and Babri 2015 |

۹. نتیجه گیری

با گسترش روزافزون متون چاپی و متون منتشرشده در فضای اینترنت، رشد اطلاعات افزایش یافته و سرریز اطلاعات رخ می‌دهد. از آنجا که پردازش دستی این داده‌های متنی کاری طاقت‌فرساست، به روش‌های متن‌کاوی احتیاج است. متن‌کاوی که تحت عناوین تجزیه و تحلیل هوشمند متن، کاوش داده‌های متنی و کشف دانش از متون نیز شناخته می‌شود، به‌طور کلی به فرایند استخراج اطلاعات و دانش جالب توجه و غیربدهی از متن بدون ساختار اشاره دارد. متن‌کاوی یک حوزه تحقیقاتی جوان و میان‌رشته‌ای بوده و در عین حال که ریشه‌ای عمیق در پردازش زبان طبیعی^۱ دارد، با فرایند کشف دانش با روش‌هایی از بازیابی اطلاعات، داده‌کاوی، آمار، یادگیری ماشین، استدلال، استخراج اطلاعات، مدیریت دانش، زبان‌شناسی محاسباتی و ... در ارتباط است. این حوزه تمام فعالیت‌هایی را که به‌نوعی به دنبال کسب دانش از متن هستند، شامل می‌گردد. تحلیل داده‌های متنی توسط تکنیک‌های یادگیری ماشین، بازیابی اطلاعات هوشمند، پردازش زبان طبیعی یا روش‌های مرتبط دیگر همگی در زمره مقوله یادگیری متن قرار می‌گیرند. اسناد متنی بر اساس محتوا به یک یا چند طبقه از قبل تعیین شده طبقه‌بندی می‌شوند، که طبقه‌بندی متون یکی از مهم‌ترین مسائل در متن‌کاوی می‌باشد. مرتب کردن بلادرنگ نام‌های الکترونیکی یا فایل‌ها در سلسله‌مراتبی از پوشه‌ها، تشخیص موضوع متن، جست‌وجوی مفهومی از متون منتشرشده، از جمله کاربردهای مبحث طبقه‌بندی (دسته‌بندی-کلاسه‌بندی) متن است. در بسیاری از موارد، افراد حرفه‌ای آموزش دیده، برای طبقه‌بندی متون جدید به کار گرفته می‌شوند. این فرایند بسیار زمان‌بر و پرهزینه است و لذا کاربرد خود را محدود می‌سازد. به همین منظور، علاقه روزافزونی به توسعه فناوری‌هایی در دسته‌بندی خودکار متن ابراز می‌شود. از طرفی با توجه به حجم گسترده آثار تحقیقاتی که به‌صورت متن ذخیره می‌شوند، انتظار می‌رود که متن‌کاوی یکی از مهم‌ترین تکنولوژی‌ها در آینده باشد. بنابراین، ایجاد یک چارچوب برای استفاده از متن‌کاوی در حفاظت از مالکیت معنوی و فکری نویسندگان و بررسی مشکلات و چالش‌های آن، زمینه تحقیقات بعدی در این حوزه را تشکیل می‌دهد. با توجه به حجم وسیع اطلاعات متنی آنلاین در دسترس، ایجاد سیستم‌های متن‌کاوی به شدت مورد نیاز است. چنین سیستمی می‌تواند در میان

1. Natural Language Processing (NLP)

گزینه‌های ممکن قرار بگیرد. این جنبه از متن کاوی با توجه به زمینه در حال رشد آن می‌تواند به‌طور مستقل بسیار جذاب باشد و از سایه متن کاوی عمومی خارج شود. این شاخه از متن کاوی برای پیش‌بینی بازار، فارغ از بحث آنالیز احساسات زمینه‌ای، بسیار امیدوارکننده است.

فهرست منابع

مصباح، سارا، و مسعود رهگذر. ۱۳۸۸. *متن کاوی*. تهران: دانشکده فنی، دانشکده مهندسی برق و کامپیوتر دانشگاه تهران.

هژیر، ابراهیم. ۱۳۹۳. *داده کاوی و مفاهیم کاربرد*. ورزقان: دانشگاه آزاد ورزقان.

Berry, M. J. A. and G. S. Linoff. 2004. *Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management*. 2nd Edition. USA: John Wiley & Sons.

Changa, Y., S. Chena, and C. Liaub. 2008. Multilabel text categorization based on a new linear classifier learning method and a category-sensitive refinement method. *Expert Systems with Applications* 34 (3): 1948–1953.

Chen, J., H. Huang, S. Tian and Y. Qu. 2009. Feature selection for text classification with Naive Bayes. *Expert Systems with Applications* 36 (3): 5432-5435.

Elmasri, R. and B. Navathe. 2000. *Fundamentals of Database Systems*. 3rd Edition, Boston, MA, USA: Addison-Wesley Longman Publishing Co.

Fayyad, U. M. 1996. Data Mining and Knowledge Discovery: Making Sense Out of Data. *IEEE Expert: Intelligent Systems and Their Applications* 11 (5): 20-25.

Fodeh, S., B. Punch, and P. N. Tan. 2011. On ontology-driven document clustering using core semantic features. *Knowledge and Information Systems* 28 (2): 395-421.

Gunal, S., S. Ergin, M.B Gulmezoglu and O.N Gerek. 2006. On feature extraction for spam email detection. *Lecture Notes in Computer Science* 4105: 635–642.

Gupta, V., and G. S. Lehal. 2009. A Survey of Text Mining Techniques and Applications. *Emerging Technologies in Web Intelligence* 1 (1): 60-76.

Hashimi, H., A. Hafez, and H. Mathkour. 2015. Selection criteria for text mining approaches. *Computers in Human Behavior* 51 (B): 729–733.

Hegna, K. and E. Murtomaa. 2003. Data Mining MARC to find FRBR?. *International Cataloguing and Bibliographic Control* 32: 52–55.

Javed, K., S. A. Maruf, and H. Babri. 2015. A two-stage Markov blanket based feature selection algorithm for text classification. *Neurocomputing* 157: 91–104.

Jiang, S., G. Pang, M. Wu and L. Kuang. 2012. An improved K-nearest-neighbor algorithm for text categorization. *Expert Systems with Applications* 39: 1503–1509.

Kanya, N., and S. Geetha. 2007. Information Extraction – a Text mining approach. Proc. of the IET-UK International Conference on Information and Communication Technology in Electrical Sciences (ICTES 2007), pp.1111-1118.

Karanikas, H., and B. Theodoulidis. 2002. Knowledge discovery in text and text mining software. Technical report, University of Manchester Institute of Science and Technology (UMIST – CRIM), Manchester.

- Kornfein, M., H. Goldfarb. 2007. A Comparison of Classification Techniques for Technical Text Passages. *Proc. Of The World Congress On Engineering 2*: 1072-1075.
- Pestov, V. 2013. Lower bounds on performance of metric tree indexing schemes for exact similarity search in high dimensions. *Algorithmica* 66 (2): 310-328.
- Rajman, M. 1997. Text Mining, Knowledge extraction from unstructured textual data. Proc. of EUROSTAT Conference, Francfort (Deutschland).
- Raymond, J. Mooney, and Un Yong Nahm. 2005. Text mining with Informatin Exteraction. In *Multilingualism and Electronic Language Management: Proceedings of the 4th International MIDP Colloquium*, W. Daelemans and T. du Plessis and C. Snyman and L. Teck (Eds.), pp. 141-160.
- Salton, G. 1989. *Automatic text processing: The transformation, analysis, and retrieval of Reading*. Boston, MA, USA: Addison-Wesley Longman Publishing Co.
- Saracoglu, R., K. Tutuncu, and N. Allahverdi. 2007. A fuzzy clustering approach for finding similar documents using a novel similarity measure. *Expert Systems with Applications* 33 (3): 600-605.
- _____. 2008. A new approach on search for similar documents with multiple categories using fuzzy clustering. *Expert Systems with Applications* 34 (4): 2545-2554.
- Schumaker, R.P., Y. Zhang, C.-N. Huang and H. Chen. 2012. Evaluating sentiment in financial news articles. *Decision Support Systems* 53 (3): 458-464.
- Suh, J. H., C. H. Park, and S. H. Jeon. 2010. Applying text and data mining techniques to forecasting the trend of petitions filed to e-People. *Expert Systems with Applications* 37 (10): 7255-7268.
- Tasci, S. and T. Gungor. 2013. Comparison of text feature selection policies and using an adaptive framework. *Expert Systems with Applications* 40 (12): 4871-4886.
- Uguz, H. 2011. A two-stage feature selection method for text categorization by using information gain, principal component analysis and genetic algorithm. *Knowledge-Based Systems* 24 (7): 1024-1032.
- Vo, D. H., and C. Y. Ock. 2015. Learning to classify short text from scientific documents using topic models with various types of knowledge. *Expert Systems with Applications* 42 (3): 1684-1698.
- Wei, T., Y. Lu, H. Chang, Q. Zhou and X. Bao. 2015. A semantic approach for text clustering using WordNet and lexical chains. *Expert Systems with Applications* 42 (4): 2264-2275.
- Weng, S., and Y. Lin. 2003. A study on searching for similar documents based on multiple concepts and distribution of concepts. *Expert Systems with Applications* 25 (3): 355-368.
- Witten, I. H. 2004. Adaptive text mining: Inferring structure from sequences. *J Discrete Algorithms* 2 (2): 137-159.
- Al Zamil, M. G. H., and A. B. Can. 2011. ROLEX-SP: Rules of lexical syntactic patterns for free text categorization. *Knowledge-Based Systems* 24 (1): 58-65.

اعظم السادات پرنی

دارای مدرک تحصیلی کارشناسی ارشد در رشته مهندسی فناوری اطلاعات گرایش تجارت الکترونیک از دانشگاه صنعتی خواجه نصیرالدین طوسی است.

تجارت الکترونیک و کسب و کار از جمله علایق پژوهشی وی است.



حجت‌اله حمیدی

متولد سال ۱۳۵۵، دارای مدرک تحصیلی دکتری در رشته مهندسی کامپیوتر- فناوری اطلاعات است. ایشان هم‌اکنون استادیار گروه فناوری اطلاعات دانشگاه صنعتی خواجه نصیرالدین طوسی است. تجارت الکترونیک، کسب‌وکار هوشمند، و محاسبات نرم از جمله علایق پژوهشی وی است.

